Registered in Germany Europa Revue Journal
ISSN: 1862-6564 Vol. 6 No. 7 (2026) Published July 25, 2026

DISTRIBUTED ENVIRONMENTAL PARAMETER MONITORING SYSTEM

Lyudmila Petrovna Varlamova

Professor, National University of Uzbekistan Doctor of Technical Sciences

Bekhzod Kamoladdin Ugli Sultanmuratov

Student, Applied Mathematics Program, National University of Uzbekistan

Mohira Muzaffar Kizi Rahimova

Master's Student, Information Systems and Technologies Program, National University of Uzbekistan

Abstract

This paper addresses the forecasting of indoor microclimate parameters (CO_2 concentration and temperature) in university classrooms using time series and machine learning models. The study was conducted using real-time IoT sensor datasets retrieved from the weather.nuu.uz platform. A comparative accuracy analysis between the classical ARIMA statistical model and a Multilayer Perceptron (MLP) neural network was performed for short-term CO_2 dynamics forecasting. Experimental results demonstrated that the machine learning approach yields superior performance under non-linear fluctuations caused by varying classroom occupancy.

Key words

Microclimate, CO_2 concentration, time series, ARIMA, machine learning, MLP, forecasting, weather.nuu.uz.

РАСПРЕДЕЛЕННАЯ СИСТЕМА МОНИТОРИНГА ПАРАМЕТРОВ ОКРУЖАЮЩЕЙ СРЕДЫ

Варламова Людмила Петровна

Профессор Национального Университета Узбекистана, доктор технических наук, e-mail: dimirel@gmail.com

Султанмуратов Бехзод Камоладдин угли

Студент направления «Прикладная математика» Национального Университета Узбекистана, e-mail: sultonmurodovbexzad@gmail.com

Рахимова Мохира Музаффар кизи

Магистрантка по направлению «Информационные системы и технологии»
Национального университета Узбекистана, e-mail:
rahimovamohira730@gmail.com

Annotatsiya

Ushbu maqolada oliy ta’lim muassasalarining o‘quv xonalaridagi mikroklimat ko‘rsatkichlarini (CO_2 konsentratsiyasi va harorat) bashorat qilish uchun vaqtli qatorlar va mashinali o‘rgatish modellarini qo‘llash masalasi ko‘rib chiqiladi. Tadqiqot weather.nuu.uz serveridan olingan real IoT-datchiklar ma’lumotlari asosida amalga oshirildi. CO_2 konsentratsiyasining dinamikasini qisqa muddatli bashorat qilish uchun ARIMA statistik modeli va ko‘p qatlamli perseptron (MLP) neyron tarmog‘ining samaradorligi o‘zaro solishtirildi. Natijalar shuni ko‘rsatdiki, neyron tarmoq modeli o‘quv xonasidagi odamlar sonining keskin o‘zgarishi sharoitida yuqori aniqlikni ta’minlaydi.

Kalit so‘zlar: Mikroklimat, CO_2 konsentratsiyasi, vaqtli qatorlar, ARIMA, mashinali o‘rgatish, MLP, bashorat qilish, weather.nuu.uz.

Аннотация

В работе рассматривается задача краткосрочного прогнозирования параметров микроклимата (концентрация CO_2 и температура) в учебных аудиториях с использованием моделей временных рядов и методов машинного обучения. Исследование выполнено на основе массива данных, полученных с датчиков автономной станции мониторинга weather.nuu.uz. Проведен сравнительный анализ точности классической статистической модели ARIMA и нейросетевой модели многослойного персептрона (MLP) при прогнозировании динамики CO_2. Экспериментально доказано преимущество методов машинного обучения в условиях нелинейных колебаний показателей, вызванных изменением числа людей в помещении.

Ключевые слова: Микроклимат, концентрация CO_2, временные ряды, ARIMA, машинное обучение, MLP, прогнозирование, weather.nuu.uz.

Введение

В современных образовательных учреждениях обеспечение оптимальных параметров микроклимата в учебных аудиториях напрямую влияет на когнитивные способности и самочувствие студентов. Повышение концентрации углекислого газа (CO_2) свыше рекомендованных норм приводит к снижению умственной активности и утомляемости [5, 10]. Ранее в работе [1] была разработана аппаратная платформа распределенного мониторинга микроклимата на базе веб-сервиса weather.nuu.uz, обеспечивающая сбор физических величин в реальном времени. Однако пассивная фиксация текущих значений не позволяет своевременно предотвращать ухудшение качества воздуха в условиях динамически меняющейся заполняемости аудиторий [10].

Переход от пассивного мониторинга к предиктивному управлению требует построения математических моделей, способных с высокой точностью прогнозировать динамику временных рядов CO_2 и температуры на заданный горизонт времени [4,5]. Сложность этой задачи заключается в выраженной нелинейности процессов: резкий приход студентов на лекцию создает скачкообразный рост показаний, в то время как естественная или принудительная вентиляция формирует экспоненциальное затухание.

В рамках данного исследования рассматриваются два принципиально разных математических подхода к прогнозированию временных рядов: классический авторегрессионный метод ARIMA (AutoRegressive Integrated Moving Average) и модель машинного обучения на основе многослойного персептрона (MLP - Multilayer Perceptron) [3].

Целью работы является разработка и сравнительный анализ алгоритмов краткосрочного прогнозирования уровня CO_2 в учебных помещениях НУУз на основе реальных массивов данных, поступающих с сервера weather.nuu.uz, для последующей интеграции в интеллектуальные системы управления вентиляцией.

Для достижения поставленной цели решаются следующие задачи:

1. Формирование и первичная очистка (фильтрация шумов) временного ряда показаний CO_2 с сервера weather.nuu.uz.

2. Математическая формализация моделей ARIMA и нейросетевого регрессора MLP.

3. Разработка программного модуля на языке Python для обучения моделей и оценки их точности по метрикам MAE и RMSE.

Основная часть: Математическое моделирование и программная реализация

Для построения прогноза уровня CO_2 непрерывный поток данных с автономной станции weather.nuu.uz дискретизируется с шагом $\Delta t = 5$ минут, формируя временной ряд $Y = \{y_1, y_2, \dots, y_t\}$, где y_t - значение прогнозируемого параметра (концентрации CO_2 или температуры воздуха) в момент времени t. Модели ARIMA и MLP применяются идентично к обоим временным рядам, различаясь лишь настроенными параметрами (порядком (p,d,q) для ARIMA и обучающей выборкой для MLP).

1. Математическая модель ARIMA(p, d, q)

Классический подход к анализу стационарных и приводимых к стационарным временных рядов основан на интеграции процессов авторегрессии (AR) и скользящего среднего (MA) [2]. Уравнение модели $ARIMA(p, d, q)$ имеет следующий вид:

$$\Delta^d y_t = c + \sum_{i=1}^{p} \phi_i \, \Delta^d y_{t-i} + \varepsilon_t + \sum_{j=1}^{q} \theta_j \, \varepsilon_{t-j}$$

где Δ^d - оператор взятия разности порядка d для приведения ряда к стационарному виду; p - порядок авторегрессии; q - порядок скользящего среднего; ϕ_i и θ_j - параметры модели; ε_t - белый шум с нулевым математическим ожиданием.

Выбор параметров модели для рассматриваемого временного ряда выполнен следующим образом. Порядок интегрирования $d = 1$определён по результатам теста Дики-Фуллера (ADF-тест): исходный ряд оказался нестационарным (p-value > 0.05), тогда как после однократного дифференцирования гипотеза о единичном корне была отвергнута (p-value < 0.05). Параметры p=2 и q=2 выбраны по

минимальному значению информационного критерия Акаике (AIC) среди перебранных комбинаций $p, q \in \{0, 1, 2, 3\}$.

2. Нейросетевая модель многослойного персептрона (MLP)

Для учета нелинейных скачков CO_2, вызванных изменением числа людей в аудитории, применяется многослойный персептрон [3]. Входной вектор модели формируется из k предыдущих отсчетов временного ряда: $X_t = [y_{t-1}, y_{t-2}, \dots, y_{t-k}]^T$.

Выходное значение сети $\hat{y}_t$ (прогноз на шаг вперед) рассчитывается через функции активации скрытых слоев:

$$\hat{y}_t = f^{(2)}\left(W^{(2)} \cdot f^{(1)}\left(W^{(1)} X_t + b^{(1)}\right) + b^{(2)}\right)$$

где $W^{(1)}, W^{(2)}$ - весовые матрицы; $b^{(1)}, b^{(2)}$ - векторы смещения; $f^{(1)}$ - нелинейная функция активации ReLU, $f^{(2)}$ - линейная функция активации выходного нейрона.

3. Оценка точности прогнозирования

Для сравнения точности работы моделей используются стандартные математические метрики: средняя абсолютная ошибка (MAE) и корень из среднеквадратичной ошибки (RMSE) [8]:

$$MAE = \frac{1}{N}\sum_{t=1}^{N} |\, y_t - \hat{y}_t|, \quad RMSE = \sqrt{\frac{1}{N}\sum_{t=1}^{N} (y_t - \hat{y}_t)^2}$$

4. Программная реализация на Python

Ниже представлен листинг модуля на Python, выполняющего загрузку временного ряда, формирование выборки и обучение нейросетевой модели MLP с использованием библиотеки scikit-learn [9]:

Листинг 1. Программный модуль краткосрочного прогнозирования CO_2 на языке Python

```
import numpy as np
import pandas as pd
from sklearn.neural_network import MLPRegressor
from sklearn.preprocessing import StandardScaler
```

```
from sklearn.metrics import mean_absolute_error, mean_squared_error


# 1. Загрузка и подготовка данных с сервера weather.nuu.uz
data = pd.read_csv('co2_data_nuu.csv')
co2_series = data['co2_ppm'].values

# 2. Формирование датасета с окном упреждения k = 6 (30 минут истории)
def create_dataset(series, k=6):
    X, Y = [], []
    for i in range(len(series) - k):
        X.append(series[i:i+k])
        Y.append(series[i+k])
    return np.array(X), np.array(Y)

X, y = create_dataset(co2_series, k=6)
split = int(len(X) * 0.8)  # 80% обучение, 20% тест
X_train, X_test = X[:split], X[split:]
y_train, y_test = y[:split], y[split:]

# 2.1. Масштабирование признаков (StandardScaler)
scaler_X = StandardScaler()
X_train_scaled = scaler_X.fit_transform(X_train)
X_test_scaled = scaler_X.transform(X_test)

scaler_y = StandardScaler()
y_train_scaled = scaler_y.fit_transform(y_train.reshape(-1, 1)).ravel()

# 3. Создание и обучение многослойного персептрона (MLP)
mlp_model = MLPRegressor(hidden_layer_sizes=(64, 32), max_iter=500, random_state=42)
mlp_model.fit(X_train_scaled, y_train_scaled)

# 4. Расчет прогноза и оценка ошибок (возврат в исходный масштаб, ppm)
y_pred_scaled = mlp_model.predict(X_test_scaled)
y_pred = scaler_y.inverse_transform(y_pred_scaled.reshape(-1, 1)).ravel()

mae = mean_absolute_error(y_test, y_pred)
```

```
rmse = np.sqrt(mean_squared_error(y_test, y_pred))
print(f"CO2 — MAE: {mae:.2f} ppm, RMSE: {rmse:.2f} ppm")


# 5. Аналогичная обработка временного ряда температуры
temp_series = data['temperature_c'].values
X_t, y_t = create_dataset(temp_series, k=6)
X_t_train, X_t_test = X_t[:split], X_t[split:]
y_t_train, y_t_test = y_t[:split], y_t[split:]


# 5.1. Масштабирование признаков для температурного ряда (отдельный scaler)
scaler_X_temp = StandardScaler()
X_t_train_scaled = scaler_X_temp.fit_transform(X_t_train)
X_t_test_scaled = scaler_X_temp.transform(X_t_test)


scaler_y_temp = StandardScaler()
y_t_train_scaled = scaler_y_temp.fit_transform(y_t_train.reshape(-1, 1)).ravel()


mlp_temp_model    =    MLPRegressor(hidden_layer_sizes=(64,    32),    max_iter=500,
random_state=42)
mlp_temp_model.fit(X_t_train_scaled, y_t_train_scaled)


y_t_pred_scaled = mlp_temp_model.predict(X_t_test_scaled)
y_t_pred = scaler_y_temp.inverse_transform(y_t_pred_scaled.reshape(-1, 1)).ravel()


mae_temp = mean_absolute_error(y_t_test, y_t_pred)
rmse_temp = np.sqrt(mean_squared_error(y_t_test, y_t_pred))
    print(f"Temperature — MAE: {mae_temp:.2f} °C, RMSE: {rmse_temp:.2f} °C")
```

Результаты исследований

Экспериментальная проверка алгоритмов проводилась на реальном массиве данных, собранном со станции мониторинга weather.nuu.uz за период с мая по июнь 2026 года в учебной аудитории НУУз [1]. Общий объем тестовой выборки составил 2016 отсчетов (соответствует 7 дням непрерывных измерений с интервалом 5 минут).

Прогноз рассчитывался на горизонт упреждения 30 минут (6 шагов вперед). Сравнительные результаты работы моделей представлены в таблице 1.

Таблица 1. Сравнительные показатели точности моделей для различных микроклиматических параметров

Анализируемый параметр	**Модель прогнозирования**	**Горизонт прогноза**	**MAE**	**RMSE**	**Характеристика работы алгоритма**
Углекислый газ (CO_2, ppm)	ARIMA(2, 1, 2)	30 мин	38.4	52.1	Запаздывание при резком входе/выходе студентов
	MLP (64x32)	30 мин	14.2	21.8	Высокая точность на нелинейных скачках
Температура (T,° C)	ARIMA(2, 1, 2)	30 мин	0.38	0.51	Устойчивый прогноз инерционного процесса
	MLP (64x32)	30 мин	0.29	0.42	Незначительный прирост точности за счет плавной динамики

Анализ результатов показывает, что статистическая модель ARIMA сглаживает пиковые значения и запаздывает при резких изменениях числа людей в аудитории (при начале и завершении пар). Модель машинного обучения MLP за счет нелинейных функций активации эффективно адаптируется к динамике временного ряда, обеспечивая сниженную ошибку MAE до 14.2 ppm, что делает её пригодной для систем автоматического управления микроклиматом [6, 7].

В отличие от концентрации CO_2, динамика температуры воздуха в помещении характеризуется высокой тепловой инерцией и плавностью изменений: приход группы студентов не вызывает мгновенных температурных скачков.

Как видно из Таблицы 1, при прогнозировании температуры разрыв в точности между статистической моделью ARIMA ($MAE = 0.38\,^{\circ}C$) и нейросетью MLP ($MAE = 0.29\,^{\circ}C$) не столь драматичен, как для CO_2. Подобное поведение объясняется тем, что температурный процесс ближе к линейно-сезонным колебаниям, где классические механизмы авторегрессии ARIMA наиболее эффективны [2, 8]. В то же время для задач предиктивного контроля CO_2 применение MLP является принципиальным, так как ошибка ARIMA на пиковых нагрузках превышает допустимые нормы [6].

Заключение

В работе решена задача построения и исследования математических моделей краткосрочного прогнозирования параметров микроклимата (CO_2 и температуры) в учебных аудиториях Национального Университета Узбекистана. Разработан программный модуль на языке Python, адаптированный для обработки временных рядов, поступающих с веб-сервера weather.nuu.uz [1].

Экспериментально доказано преимущество нейросетевой модели MLP перед классическим методом ARIMA при анализе нелинейных процессов: при прогнозировании уровня CO_2 точность модели повысилась более чем в 2.5 раза ($MAE = 14.2$ ppm против 38.4 ppm). В то же время установлено, что для инерционных процессов (динамика температуры) классическая модель ARIMA показывает сопоставимые результаты с нейросетевым подходом ($MAE = 0.38\,^{\circ}C$ против $0.29\,^{\circ}C$).

Полученные результаты позволяют использовать разработанную модель в составе интеллектуального контроллера принудительной вентиляции для упреждающего проветривания помещений до достижения критических концентраций углекислого газа и поддержания комфортного температурного режима [5, 10].

Использованная литература

1. Варламова Л. П., Султанмурадов Б., Бобокулов А. Распределенная система мониторинга параметров окружающей среды // Development of Science. -2026. - Vol. 2, Issue 6. - ISSN 3030-3907.

2. Бокс Дж., Дженкинс Г. Анализ временных рядов. Прогноз и управление. - М.: Мир, 1974. - 406 с.

3. Хайкин С. Нейронные сети: полный курс. - 2-е изд. - М.: Издательский дом «Вильямс», 2006. - 1104 с.

4. Айвазян С. А. Прикладная статистика и основы аналитики данных. - М.: Юрайт, 2020. - 412 с.

5. Гуров А. А., Кузнецов В. М. Применение нейросетевых моделей для анализа микроклиматических параметров умных зданий // Автоматика и телемеханика. - 2023. - № 4. - С. 45–58.

6. Muller A., Sarah L., Chen X. Indoor CO_2 Concentration Forecasting using Time-Series Machine Learning Models // IEEE Transactions on Building Automation. - 2024. - Vol. 18, No. 2. - Pp. 112–124.

7. Zhang Y., Li H., Wang J. Deep Learning Approaches for Smart Campus Indoor Air Quality Prediction // Building and Environment. - 2023. - Vol. 230. - Art. 110012.

8. Ширяев А. Н. Вероятностно-статистические методы в задачах прогнозирования временных рядов. - М.: Наука, 2021. - 280 с.

9. Pedregosa F. et al. Scikit-learn: Machine Learning in Python // Journal of Machine Learning Research. - 2011. - Vol. 12. - Pp. 2825–2830.

10. Касимов А. О., Ниязов Б. Р. Моделирование систем микроклимата в учебных заведениях // Вестник Национального университета Узбекистана. - 2025. - № 2. - С. 89–96.